

WEEKLY REPORT

张建伟

April 1, 2019

1 上周工作

1.1 肝肿瘤分割

- 由于增加了 spatial guide 和 density histogram 分支后模型增加较多, 所以本周完成了多 GPU 训练的代码.

2 下周工作

- 对当前的半自动肿瘤分割模型进行调参.
- 整理更加详细的分割流程和实验思路.

3 论文阅读

3.1 Instance Normalization: The Missing Ingredient for Fast Stylization

本文提出了 Instance Normalization. 原始的 Batch Normalization 是使用一个特征层输出的 spatial 和 batch 轴计算统计量, 而在风格迁移任务中一个 batch 中不同的图片所对应的目标不同, 因此计算统计量时移除 batch 轴, 只对 spatial 轴做能够提升风格迁移图像的效果. 下面依次为 BN 和 IN 的表达式.

$$y_{tijk} = \frac{x_{tijk} - \mu_i}{\sqrt{\sigma_i^2 + \epsilon}}, \quad \mu_i = \frac{1}{HWT} \sum_{t=1}^T \sum_{l=1}^W \sum_{m=1}^H x_{tilm}, \quad \sigma_i^2 = \frac{1}{HWT} \sum_{t=1}^T \sum_{l=1}^W \sum_{m=1}^H (x_{tilm} - \mu_i)^2. \quad (2)$$

In order to combine the effects of instance-specific normalization and batch normalization, we propose to replace the latter by the *instance normalization* (also known as “contrast normalization”) layer:

$$y_{tijk} = \frac{x_{tijk} - \mu_{ti}}{\sqrt{\sigma_{ti}^2 + \epsilon}}, \quad \mu_{ti} = \frac{1}{HW} \sum_{l=1}^W \sum_{m=1}^H x_{tilm}, \quad \sigma_{ti}^2 = \frac{1}{HW} \sum_{l=1}^W \sum_{m=1}^H (x_{tilm} - \mu_{ti})^2. \quad (3)$$

We replace batch normalization with instance normalization everywhere in the generator network g . This prevents instance-specific mean and covariance shift simplifying the learning process. Differently from batch normalization, furthermore, the instance normalization layer is applied at test time as well.

Figure 1

3.2 A Learned Representation for Artistic Style

本文仍然针对风格迁移问题, 为了能让同一个模型对多种风格进行迁移, 本文修改了 instance normalization 层, 把缩放参数 γ 和平移参数 β 变为 $N \times C$ 的大小 (原来是 C , 对应通道数), 这里的 N 即为风格的数量. 本文任务不同风格迁移时, 图像的统计量是可以共享的, 而不同的风格取决于不同的缩放参数和平移参数. 因此使用不同的风格图像训练时选用不同的参数. 这种方式称为 conditional instance normalization, CIN, 表达式为

$$z = \gamma_s \left(\frac{x - \mu}{\sigma} \right) + \beta_s$$

3.3 Arbitrary Style Transfer in Real-time with Adaptive Instance Normalization

本文提出了 Adaptive Instance Normalization(AdaIN). 上一篇文章虽然多个风格图片可以使用同一个模型, 但是仍然有局限性, 即在不进一步训练的情况下无法扩展到其他风格图像. 因此本文修改了 IN 的表达式

$$AdaIN(x, y) = \sigma(y) \left(\frac{x - \mu(x)}{\sigma(x)} \right) + \mu(y).$$

即不再使用可训练参数, 缩放参数和平移参数由风格图像 y 在该层特征的统计量来表示. 这样风格图像的风格信息不再需要硬编码到模型中, 从而实现了自适应的风格迁移. 模型结构如下图

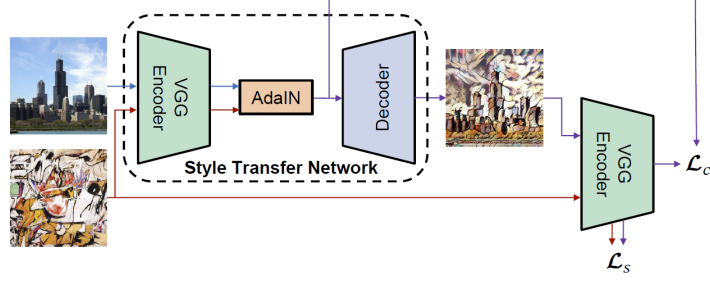


Figure 2

3.4 RA-UNet: A hybrid deep attention-aware network to extract liver and tumor in CT scans

本文对 UNet 的结构做了一些修改, 使用 ResBlock 代替了原来的卷积操作, 并在 skip connection 上增加了 attention 模块.

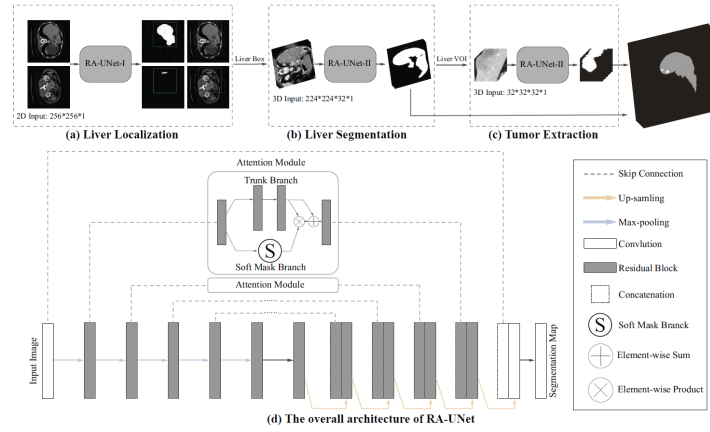


Figure 3